(19)日本国特許庁（ＪＰ）　(12) 公開特許公報（A）　(11)特許出願公開番号

特開平4－318684

(43)公開日　平成４年(1992)11月10日

(51)Int.Cl.[5]	識別記号	庁内整理番号	ＦＩ	技術表示箇所
Ｇ０６Ｆ　15/70	４６５　Ｚ	9071－5L		
7/24		8323－5B		

審査請求　未請求　請求項の数１(全　6　頁)

(21)出願番号　特願平3－85556

(22)出願日　平成３年(1991)４月17日

(71)出願人　000006208
三菱重工業株式会社
東京都千代田区丸の内二丁目５番１号

(72)発明者　川瀬　直人
兵庫県神戸市兵庫区和田崎町一丁目１番１号　三菱重工業株式会社神戸造船所内

(72)発明者　川田　かよ子
兵庫県神戸市兵庫区和田崎町一丁目１番１号　三菱重工業株式会社神戸造船所内

(72)発明者　宮本　一正
兵庫県神戸市兵庫区和田崎町一丁目１番１号　三菱重工業株式会社神戸造船所内

(74)代理人　弁理士　鈴江　武彦

(54)【発明の名称】　データ分類装置

(57)【要約】

【目的】データ分類装置において、データの分布状況を考慮してより正しいデータの分類を可能にする。

【構成】テンプレート作成装置１、ユークリッドクラス判定装置２、矯正クラス判定装置３、収束判定装置４を有すると共に、特徴ベクトルデータと、どのデータがどのクラスに属するかを示すクラスデータと、処理上一時的に発生するデータを記憶するためのメモリ５を有する。分類処理の最初のステップでは種データからのテンプレートのみを利用して、ユークリッド距離でデータを一時的にクラス分けし、その後のステップでは、一時的にクラス分けしたデータからテンプレートとテンプレート補助データを生成し、それを利用して全体を矯正距離により再分類し、このステップを収束するまで繰り返すことにより、種データを基にデータ全体の分類を可能にしたものである。

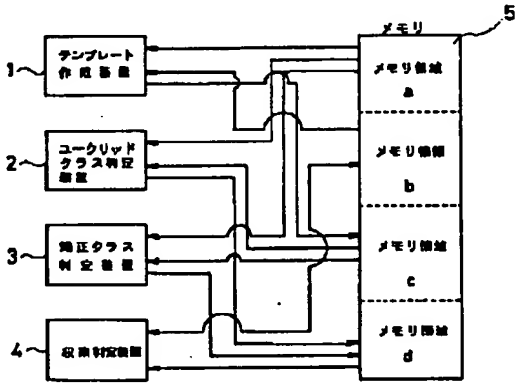

1

【特許請求の範囲】

【請求項1】　複数個の特徴量ベクトルで表現されるデータ群で、それぞれデータに対して属するクラスがある場合に、各クラスについて正しいクラスが判っている種データと、正しいクラスが判らない多数の分類データが与えられた時に、特徴ベクトルデータと、どのデータがどのクラスに属するかを示すクラスデータと、処理上一時的に発生するデータを記憶するためのメモリを有し、上記種データを基にデータ全体を分類するデータ分類装置において、クラスデータを参照して、その対応する特徴ベクトルからクラス毎にテンプレート（平均ベクトル）と、平均に関する共分散行列の固有値と固有ベクトルの全部または1部を用いたテンプレート補助データを作成するテンプレート作成装置と、クラスを識別すべきデータの特徴量ベクトルと各クラスのテンプレートとのユークリッド距離からデータのクラスを判定するユークリッドクラス判定装置と、クラスを識別すべきデータの特徴量ベクトルと各クラスのテンプレートとのユークリッド距離を、上記テンプレート作成装置で生成したテンプレート補助データを用いて、クラスの分布状態に対する相対距離に矯正し、この強制距離からデータのクラスを判定する矯正クラス判定装置と、全てのデータに対する今回のクラス判定結果が、前回のクラス判定結果と一致している時、分類が収束したとみなす収束判定装置とを具備し、最初のステップでは種データからのテンプレートのみを利用して、ユークリッド距離でデータを一時的にクラス分けし、その後のステップでは、一時的にクラス分けしたデータからテンプレートとテンプレート補助データを生成し、それを利用して全体を矯正距離により再分類し、このステップを収束するまで繰り返すことにより、種データを基にデータ全体の分類を行なうことを特徴とするデータ分類装置。

【発明の詳細な説明】

【0001】

【産業上の利用分野】本発明は、文字データ等のデータ収集に際して、オペレータが収集データ毎にデータの属するクラスを入力する手間を省くことを可能にするデータ分類装置に関する。

【0002】

【従来の技術】少数の正解データを参考にデータ群全てを分類することを、一般的にクラスタリングと呼ぶが、そのアルゴリズムは以下のようになる。

【0003】（1）r個のクラスが存在するとして、ω_1, ω_2, …, ω_r をそれぞれのクラスに属するデータの集合とする。初期状態においては、最初に分かっている正解データのみがω_iの要素である。

（2）集合ω_iの要素の中心（すなわちテンプレート）m_iを求める。全てのクラスに対してm_iを求める。

（3）全てのデータxについて、テンプレートm_iから距離D_i^2が最小になるiを求める。xを新たな分類結果の集合ω_i'に属するものとする。

2

（4）$\omega_i = \omega_i'$がすべてのクラスiについて成立すれば、このアルゴリズムは終了する。そうでなければω_i'を新たにω_iとし（2）に戻る。従来のクラスタリングでは、距離D_i^2の定義は通常ユークリッド距離、すなわち、

$D_i^2 = {}^t(x-m_i)(x-m_i)$

を使用していた。

【0004】

【発明が解決しようとする課題】距離としてユークリッド距離を用いる方式では、以下のようなケースにおいて誤分類する確率が高くなる。

（a）1つのクラスが複数個の集団に分かれて分布する。（図3（i））

（b）クラスの分布が偏向性を持つ。（図3（ii））

（c）クラスによって分布のばらつき度が大きく異なる。（図3（iii））そこで分布のばらつき度を考慮した距離を用いる必要がある。そのような距離の代表例としてはマハラノビス距離がある。その定義は次のようになる。

$D_i^2 = {}^t(x-m_i)V_i^{-1}(x-m_i)$

V_i：クラスiのデータの共分散行列

なお、距離D_iとしてマハラノビス距離を用いる場合には、テンプレート計算時にテンプレート補助データとしてV_iを求める必要がある。しかし、次のような場合には、共分散行列V_iが正則でない、あるいは計算上正則とはいえないためマハラノビス距離が定義できない。

（d）特徴量ベクトルにおいて、その要素となる特徴量間の相関が非常に大きい時。（例、一方向に伸縮する幾何図形データの周長と面積。）

（e）常に一定値をとるような無意味な特徴量がある時。（例、ひらがな2値画像データにおける周辺ピクセル値。通常0になる。）

【0005】本発明は上記実情に鑑みてなされたもので、データの分布状況を考慮してより正しいデータの分類を行なうことができ、データ収集に際して、オペレータが収集データ毎にデータの属するクラスを入力する手間を省くことができるデータ分類装置を提供することを目的とする。

【0006】

【課題を解決するための手段】本発明に係るデータ分類装置は、クラスデータを参照して、その対応する特徴ベクトルからクラス毎にテンプレート（平均ベクトル）と、平均に関する共分散行列の固有値と固有ベクトルの全部または1部を用いたテンプレート補助データを作成することを特徴とするテンプレート作成装置と、クラスを識別すべきデータの特徴量ベクトルと各クラスのテンプレートとのユークリッド距離から、データのクラスを判定するユークリッドクラス判定装置と、クラスを識別

すべきデータの特徴量ベクトルと各クラスのテンプレートとのユークリッド距離を、上記テンプレート作成装置で生成したテンプレート補助データを用いて、クラスの分布状態に対する相対距離に矯正し、この矯正距離からデータのクラスを判定する矯正クラス判定装置と、全てのデータに対する今回のクラス判定結果が、前回のクラス判定結果と一致している時、分類が収束したとみなす収束判定装置とを具備したことを特徴とするものである。

【0007】

【作用】メモリは、特徴量ベクトルを記憶する領域a、クラスデータを記憶する領域b、テンプレートとテンプレート補助データを記憶する領域c、一時的に分類されたクラス（一時的なクラスデータ）を記憶する領域dから成り立つものとする。

【0008】また、初期状態において分類データの特徴量ベクトル、種データの特徴量ベクトルが領域aに、種データのクラスデータが領域bにセットされているものとする。各装置は以下の順で動作する。まず初期動作として、

【0009】（1）テンプレート作成装置がクラスデータ（クラスID）を領域bから、またそれ（クラスID）に対応する種データ特徴量ベクトルを領域aから読み込み、テンプレートを作成し領域cに記憶する。

【0010】（2）ユークリッドクラス判定装置が、特徴量ベクトル（分類データ、種データ）を領域aから、テンプレートを領域cから読み込み、各特徴量ベクトル毎に各クラスへのユークリッド距離を計算し各特徴量ベクトルの属するクラスを判定し、クラスデータをデータIDと共に領域dに記憶し、これを領域bへコピーする。これにより領域bに記載されているクラスデータは、分類データ、種データの区別のない最新のクラスデータとなる。以下繰り返し動作として、

【0011】（3）テンプレート作成装置がクラスデータ（クラスID）を領域b（上記（2）でコピーされたもの）から、またクラスデータ（クラスID）に対応する特徴量ベクトルを全て領域aから読み込み、テンプレートとテンプレート補助データを作成し、それを領域cに記憶する。

【0012】（4）矯正クラス判定装置が特徴量ベクトルを全て領域aから、テンプレート、テンプレート補助データを領域cから読み込み、各特徴量ベクトル毎に各クラスへの相対距離を計算し各特徴量ベクトルの属するクラスを判定し、クラスデータをデータIDと共に領域dに記憶する。

（5）収束判定装置が、領域b内のクラスデータ（上記（2）でコピーされたもの）と、今回の部類結果であるクラスデータを領域dから読み込み比較する。

【0013】両方のクラスデータ（各データIDについての）が全て一致していれば収束したと判断する。このときの領域bの内容が最終的な分類結果となる。一致していない時には、今回の分類結果（dに記憶されているクラスデータ）を領域bへコピーするとともに、上記（3）から再動作させる。

【0014】矯正クラス判定装置において言及している相対距離とは、クラスタリングにおける距離D_i^2のことであるが、問題点に対処するために次に説明する距離を用いる。あるクラスのm行m列共分散行列Vの固有値を大きい順に

$\lambda_1 \geq \lambda_2 \geq \cdots \lambda_m \geq 0$

とし、対応する正規化された固有ベクトルを

$v_1, v_2, \cdots, v_m$

とする。課題で述べた理由により共分散行列が非正則、あるいは非正則に近い場合には$i \geq j$ならば

$\lambda_i \neq 0$

【0015】となる整数jが存在する。そこで、$\lambda_c > 0$である一定の閾値λ_cを定め、$\lambda_i \geq \lambda_c$となるλ_iに対応する固有ベクトルが張る部分空間に対してはマハラノビス距離d_Mを適用し、

【0016】

【数1】

$$d_M^2 = \sum_{i=1}^{K} \frac{(x-m,\ v_i)^2}{\lambda_i} \quad （但し\ \lambda_K \geq \lambda_c）$$

残りの直交ほ空間に対して、ユークリッド距離d_E

$$d_E^2 = \sum_{i=K+1}^{m} \frac{(x-m,\ v_i)^2}{\lambda_c}$$

を導入し、これらを統合して新たな距離を定義し、

それをD_iとして用いる。

$$d_i^2 = \sum_{i=1}^{m} \frac{(x-m,\ v_i)^2}{\lambda_c} - \sum_{i=1}^{K} \left(1 - \frac{\lambda_c}{\lambda_i}\right) \frac{(x-m,\ v_i)^2}{\lambda_c}$$

5

【0017】このような距離を用いるために、テンプレート補助データとして、各クラスに対する閾値λ_tより大きい複数個の固有値とそれに対応する固有ベクトルを計算する。この装置の動作原理を概念的に説明すると次のようになる。

【0018】まず、初期分類はユークリッド距離を用いて行なわれるが、この分類により大半のデータは正しく分類される。そのため、その結果を用いて作成されたテンプレートとその補助データは、完全ではないがおおよそのクラスに関する分布情報を持つことになる。

【0019】次にそのテンプレートと補助データを用いた相対距離による分類は、分布情報の利用により前回よりも正しく分類される。このため、その結果を用いて作成されたテンプレートとその補助データは、前回よりも更に正確な分布情報を示していることになる。以上の動作を繰り返すことにより、データが正しく分類される比率が次第に高くなっていく。

【0020】

【実施例】以下、図面を参照して本発明の一実施例を説明する。具体例として、文字の画像データから得られた特徴量により、画像の示す文字（＝クラス）を分類するデータ分類装置を考える。

6

*【0021】図1は本発明の一実施例に係わるデータ分類装置の全体構成を示すものである。同図において、1はテンプレート作成装置、2はユークリッドクラス判定装置、3は矯正クラス判定装置、4は収束判定装置である。また、5はメモリで、特徴量ベクトルを記憶する領域a、クラスデータを記憶する領域b、テンプレートとテンプレート補助データを記憶する領域c、一時的に分類されたクラス（一時的なクラスデータ）を記憶する領域dからなり、上記テンプレート作成装置1、ユークリッドクラス判定装置2、矯正クラス判定装置3、収束判定装置4によりアクセスされる。また、上記メモリ5には、初期状態において、分類データの特徴量ベクトル及び種データ（各クラスについて正しいクラスが判っているデータで1個以上あれば良い）の特徴量ベクトルが領域aに、種データのクラスデータが領域bにセットされているものとする。次に上記実施例におけるデータ分類方式について説明する。まず、変数の定義を行なう。

$n(k)$：クラスkのサンプルデータ数

x^k_l：クラスkのサンプルデータの特徴量ベクトル（$l=1\sim n(k)$）

【0022】

*【数2】

$$m^k \quad :1/n(k)\sum_{l=1}^{n(k)} x^k_l \quad \text{クラスkの特徴ベクトルの平均}$$

$$V^k \quad :1/n(k)\sum_{l=1}^{n(k)} (x^k_l - m^k)^t (x^k_l - m^k)$$

クラスkのm^kに関する共分散行列

λ^k_j：V^kの固有値（$\lambda^k_j \geq \lambda^k_{j+1}$）

v^k_j：λ^k_jに対応する固有ベクトル（$j=1\sim m$、mは特徴量数）

λ_t：固有値しきい値

以下、図2のフローチャートに示す手順で動作する。

（a）初期設定（ステップA1）

【0023】初期状態では、分類データ（正しいクラスの判らない多数のデータ）、種データ（各クラスについて正しいクラスが判っているデータ）に対する特徴量ベクトルをメモリ5のメモリ領域aに記憶させる。データの識別のために各特徴量ベクトルには一意な番号即ちデータIDが割り振られている。ここでは分類データ、種データ合わせて1から順に番号を付ける。

【0024】メモリ5のメモリ領域bとメモリ領域dは共に同じ構成であり、クラスデータが記憶される。各クラスデータにはデータIDが伴っており、クラスデータのデータIDを参照して、対応する特徴量ベクトルを領域aから必ず見つけ出せるようになっている。初期状態では、種データに対するクラスデータのみをメモリ領域bに記憶させる。

（b）初期テンプレートの作成（ステップA2）

【0025】テンプレート作成装置1がメモリ領域bからクラスデータ（クラスID）を読み込み、そのクラスデータに対応する種データの特徴量ベクトルをメモリ領域aから読み込む。この段階ではメモリ領域bには種データに関するクラスデータのみが記憶されており、テンプレートm^kは種データから作成され、このテンプレートをメモリ領域cに記憶させる。

（c）初期分類（ステップA3）

ユークリッドクラス判定装置2が各データに対するクラスを判定し、初期分類を行なう。

【0026】ユークリッドクラス判定装置2は、メモリ領域aから特徴量ベクトル（分類データ、種データ）を読み込み、その各特徴量ベクトルのテンプレートをメモリ領域cから読み込み、各特徴量ベクトル毎に各クラスのユークリッド距離を求める。このユークリッド距離が最も小さくなるクラスを特徴量ベクトルに対するクラスであると判定し、その判定結果、即ち、クラスデータをデータIDと共にメモリ領域dに記憶し、これをメモリ領域bにコピーする。これによりメモリ領域bに記憶されているデータは、分類データ、種データの区別のない最新のクラスデータとなる。以上で全てのデータが一時

的にクラス分けされた状態になっている。次に以下に示すステップA4 ～A6 の動作を繰り返して実行する。

（d）テンプレートの作成（ステップA4 ）

テンプレート作成装置１がテンプレートを作成する。

【００２７】テンプレート作成装置１は、メモリ領域ｂからクラスデータ（クラスＩＤ）（ステップA3 でコピーされたもの）を読み込み、そのクラスデータに対応する種データの特徴量ベクトルをメモリ領域ａから読み込む。このデータを使って各クラス毎に、平均m^k 、固有値$\lambda^k{}_i$ 、固有ベクトル$v^k{}_i$ を求める。平均m^k をテンプレート、λ_i より大きい固有値とそれに対応する固有ベクトルをテンプレート補助データとしてメモリ領域ｃに記憶する。

（e）データ分類（ステップA5 ）

矯正クラス判定装置３が各データに対するクラスを判定する。

【００２８】矯正クラス判定装置３は、メモリ領域ａから特徴量ベクトルを読み込み、メモリ領域ｃから各特徴量ベクトルに対するテンプレート及び補助テンプレートデータを読み込み、各特徴量ベクトル毎に各クラスへの相対距離を求める。そして、相対距離が最も小さくなるクラスをその特徴量ベクトルに対するクラスであると判定し、クラスデータをデータＩＤと共にメモリ領域ｄに記憶する。

（f）収束判定（ステップA6 ）

収束判定装置４が、収束しているかどうかを判定する。

【００２９】収束判定装置４は、メモリ領域ｂ内のクラスデータ（ステップA3 でコピーされたもの）と、メモリ領域ｄに記憶されている今回の分類結果であるクラスデータとを比較し、収束しているかどうかを調べる。メモリ領域ｄのすべてのクラスデータに対して、メモリ領域ｂ内に対応するクラスデータのクラスが一致していれば収束していると判断する。このときのメモリ領域ｂの内容が最終的な分類結果となる。一致していない、つまり、収束していなければ、メモリ領域ｄに記憶している

今回の分類結果をメモリ領域ｂにコピーし、ステップA4 から再実行する。

【００３０】上記のように分類処理の最初のステップでは種データからのテンプレートのみを利用して、ユークリッド距離でデータを一時的にクラス分けし、その後のステップでは、一時的にクラス分けしたデータからテンプレートとテンプレート補助データを生成し、それを利用して全体を矯正距離により再分類し、このステップを収束するまで繰り返すことにより、種データを基にデータ全体の分類を可能にするもので、これによりデータの分類状況を考慮してより正しいデータの分類を行なうことができる。なお、本発明は、少数の正解データを参考にして、データ群全てを分類することが必要な全ての装置において適用し得るものである。

【００３１】

【発明の効果】以上詳記したように本発明によれば、複数個の特徴量で表現されるデータ群で、それぞれのデータに対して属するべきクラスがある場合に、各クラスについて正しいクラスが分かっている少数個のデータと、正しいクラスが分からない多数のデータが与えられた時に、少数の正解データを元にデータ全体の分類を可能にする装置において、データの分布状況を考慮してより正しいデータの分類を行なうことができ、文字データ等のデータ収集に際して、オペレータが収集データ毎にデータの属するクラスを入力する手間を省くことができる。

【図面の簡単な説明】

【図１】本発明の一実施例に係るデータ分類装置の全体構成を示すブロック図。

【図２】本発明の動作を示すフローチャート。

【図３】誤分類が発生し易いケースの説明図。

【符号の説明】

１…テンプレート作成装置、２…ユークリッドクラス判定装置、３…矯正クラス判定装置、４…収束判定装置、５…メモリ。

【図1】

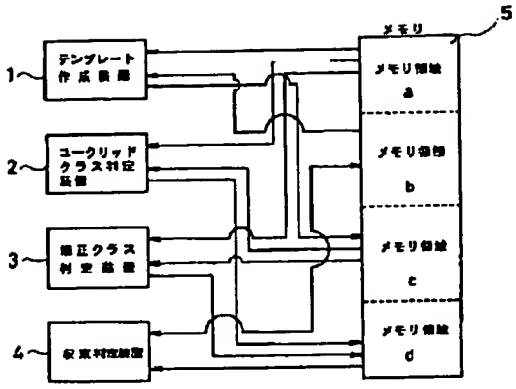

【図2】

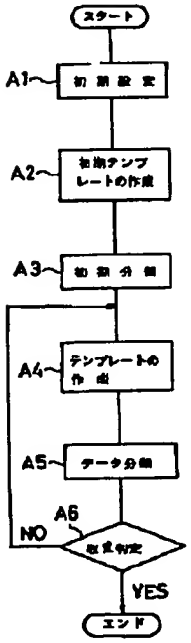

【図3】

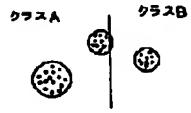

(i) 1つのクラスが複数個のクラスに別れて分布

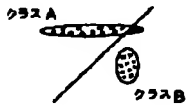

(ii) クラスの分布が負向性を持つ分布

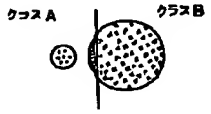

(iii) クラスによって分布のばらつき度が大きく異なる分布

図　誤分類を生じる領域